

Περιεχόμενα

Κατάλογος Σχημάτων	xii
Κατάλογος Πινάκων	xviii
1 Εισαγωγή	1
1.1 Κίνητρα για Αποθήκες και Εξόρυξη Δεδομένων	2
1.2 Αποθήκες Δεδομένων και Εξόρυξη Δεδομένων	5
1.3 Διαδικασία KDD	7
1.4 Λειτουργίες Εξόρυξης και Εφαρμογές	9
1.5 Σκοποί του Βιβλίου	10
1.6 Ιστορικό και Βιβλιογραφία	11
2 Επεξεργασία Δεδομένων	13
2.1 Μορφή και Ιδιότητες Δεδομένων	14
2.2 Περίληψη Δεδομένων	15
2.3 Καθαρισμός και Μετασχηματισμός Δεδομένων	18
2.3.1 Καθαρισμός δεδομένων	19
2.3.2 Μετασχηματισμός δεδομένων	25
2.4 Κβαντοποίηση Αριθμητικών Ιδιοτήτων	27
2.4.1 Αλγόριθμοι κβαντοποίησης	27
2.5 Τυχαία Δειγματοληψία	32
2.5.1 Απλή τυχαία δειγματοληψία	33
2.5.2 Στρωματοποιημένη δειγματοληψία	38
2.6 Μείωση Αριθμού Διαστάσεων	40
2.6.1 Ανάλυση Πρωταρχικών Συνιστώσων	41
2.6.2 Επιλογή χαρακτηριστικών	46
2.7 Μέτρα Ομοιότητας και Απόστασης	49
2.7.1 Ιδιότητες μέτρων ομοιότητας και απόστασης	49

2.7.2 Γνωστά μέτρα ομοιότητας και απόστασης	51
2.8 Ασκήσεις	59
3 Αποθήκες Δεδομένων και OLAP	61
3.1 Κίνητρα Ανάπτυξης Αποθηκών Δεδομένων	62
3.2 Ορισμός Αποθήκης Δεδομένων	65
3.3 Αρχιτεκτονική Αποθήκης Δεδομένων	67
3.3.1 Επιχειρησιακές βάσεις δεδομένων	67
3.3.2 Περιοχή προετοιμασίας δεδομένων	67
3.3.3 Περιοχή παρουσίασης δεδομένων	70
3.3.4 Εργαλεία προσπέλασης δεδομένων	71
3.4 Κύβος Δεδομένων και Σχήμα Αστέρα	71
3.4.1 Κύβος δεδομένων	71
3.4.2 Σχήμα αστέρα	73
3.5 Πράξεις OLAP	74
3.6 Ασκήσεις	77
4 Μοντελοποίηση με Διαστάσεις	79
4.1 Τέσσερα Σχεδιαστικά Βήματα	80
4.1.1 Σχήμα Αστέρα	83
4.1.2 Σχήματα Χιονονιφάδας και Γαλαξία	84
4.2 Ιδιότητες Πινάκων Διαστάσεων	84
4.2.1 Ονόματα ιδιοτήτων και επιλογή κλειδιών	84
4.2.2 Ιεραρχίες και αποκανονικοποίηση	88
4.3 Τρεις Τύποι Πινάκων Γεγονότων	89
4.3.1 Πίνακες γεγονότων συναλλαγών	90
4.3.2 Πίνακες γεγονότων περιοδικής φωτογράφησης	91
4.3.3 Πίνακες γεγονότων συσσωρευτικής φωτογράφησης	93
4.3.4 Σύγκριση τριών τύπων πινάκων γεγονότων	95
4.4 Σχεδιασμός Σύμφωνων Πινάκων Διαστάσεων	96
4.5 Μεταβολές στους Πίνακες Διαστάσεων	98
4.5.1 Αργά μεταβαλλόμενοι πίνακες διαστάσεων	98
4.5.2 Γρήγορα μεταβαλλόμενοι πίνακες διαστάσεων	101
4.6 Ασκήσεις	102
5 Φυσικό Επίπεδο Αποθηκών Δεδομένων	105
5.1 Τύποι Συστημάτων OLAP	106
5.1.1 Συστήματα MOLAP	106
5.1.2 Συστήματα ROLAP	107

5.1.3	Συστήματα HOLAP	108
5.2	Υλοποίηση Κυβοειδών σε Κύβους Δεδομένων	108
5.2.1	Κυβοειδή και ο τελεστής CUBE	108
5.2.2	Υλοποιημένα κυβοειδή	110
5.2.3	Επιλογή κυβοειδών προς υλοποίηση	113
5.3	Δομές Καταλόγου για OLAP	116
5.3.1	Κατάλογοι bitmap	117
5.3.2	Κατάλογοι σύνδεσης	118
5.4	Ασκήσεις	121
6	Κατηγοριοποίηση	123
6.1	Μοντέλο Κατηγοριοποίησης	124
6.2	Τύποι Κατηγοριοποιητών	125
6.3	Κριτήρια Αξιολόγησης Κατηγοριοποιητών	129
6.3.1	Ακρίβεια πρόβλεψης μοντέλου	129
6.3.2	Ευκολία κατανόησης μοντέλου	131
6.3.3	Κλιμακώση μεγέθους συνόλου εκπαίδευσης	131
6.3.4	Ανοχή σε θόρυβο και ελλιπείς τιμές	132
6.4	Βασικοί Κατηγοριοποιητές	132
6.4.1	Δένδρα Απόφασης	132
6.5	Bayesian Κατηγοριοποιητές	146
6.5.1	Ορισμός Bayesian Κατηγοριοποιητών	146
6.5.2	Αφελείς Bayesian Κατηγοριοποιητές	148
6.5.3	Bayesian Belief Δίκτυα	151
6.5.4	Κατηγοριοποιητές k Πλησιέστερων Γειτόνων	152
6.6	Αποτίμηση Ακρίβειας Κατηγοριοποιητών	155
6.6.1	Μέθοδοι αποτίμησης ακρίβειας	155
6.6.2	Διαστήματα εμπιστοσύνης εκτιμώμενης ακρίβειας	157
6.7	Βελτίωση Ακρίβειας Κατηγοριοποιητών	158
6.7.1	Υπερβολική προσαρμογή και κλάδεμα	158
6.7.2	Σύνολα κατηγοριοποιητών	163
6.8	Κλιμακούμενοι Αλγόριθμοι Κατηγοριοποίησης	165
6.8.1	Αλγόριθμος SLIQ	165
6.8.2	Αλγόριθμος SPRINT	170
6.9	Ασκήσεις	173

7 Ομαδοποίηση	175
7.1 Ιεραρχική Ομαδοποίηση	177
7.1.1 Συναθροιστικός ιεραρχικός αλγόριθμος ομαδοποίησης	177
7.1.2 Αλγόριθμοι μονής και πλήρους σύνδεσης	180
7.1.3 Γενικευμένα μέτρα απόστασης ομάδων	185
7.2 Αλγόριθμοι Τμηματοποίησης	189
7.2.1 Απευθείας επίλυση	189
7.2.2 Αλγόριθμος k-Means	192
7.2.3 Αλγόριθμος Πλησιέστερων Γειτόνων	198
7.3 Αλγόριθμος DBScan	200
7.4 Αλγόριθμοι Βασισμένοι στη Θεωρία Γράφων	204
7.5 Κλαμακούμενοι Αλγόριθμοι Ομαδοποίησης	209
7.5.1 Αλγόριθμος BIRCH	210
7.5.2 Αλγόριθμος Chameleon	212
7.6 Έλεγχος Εγκυρότητας Ομάδων	215
7.6.1 Εγκυρότητα με εσωτερικά χριτήρια	215
7.6.2 Εγκυρότητα με εξωτερικά χριτήρια	222
7.7 Τάση Ομαδοποίησης	223
7.8 Ασκήσεις	228
8 Συσχέτιση	231
8.1 Κανόνες Συσχέτισης	232
8.2 Αλγόριθμος Apriori	234
8.2.1 Κριτήριο περικοπής του Apriori	235
8.2.2 Αλγόριθμος δημιουργίας και εξέτασης υποψηφίων	236
8.2.3 Μέτρηση υποστήριξης	239
8.3 Παραγωγή Κανόνων Συσχέτισης	241
8.4 Βελτιώσεις Αλγορίθμου Apriori	243
8.5 Αλγόριθμος FP-Growth	246
8.5.1 FP-δένδρο	246
8.5.2 Εύρεση συχνών συνόλων	248
8.6 Κλειστά Σύνολα Αντικειμένων	251
8.7 Μειονεκτήματα Μέτρου Εμπιστοσύνης	253
8.8 Χρήση Περιορισμών	256
8.9 Ασκήσεις	257

9 Εφαρμογή με Analysis Services	261
9.1 Κύβοι Δεδομένων	262
9.1.1 Δημιουργία κύβου	262
9.1.2 Προβολή αποτελέσματος	292
9.2 Κατηγοριοποίηση	293
9.2.1 Δένδρα απόφασης	293
9.2.2 Αφελείς Bayesian κατηγοριοποιητές	310
9.3 Ομαδοποίηση	318
9.3.1 Βασικές ρυθμίσεις	318
9.3.2 Παράμετροι	322
9.3.3 Προβολή των ομάδων	324
9.3.4 Αξιολόγηση του μοντέλου	330
9.4 Συσχέτιση	334
9.4.1 Βασικές ρυθμίσεις	334
9.4.2 Παράμετροι	337
9.4.3 Προβολή itemsets	339
9.4.4 Προβολή κανόνων	342
9.5 Ασκήσεις	345
Βιβλιογραφία	346
Ευρετήριο	354